

Primljen / Received: 15.9.2015.

Ispravljen / Corrected: 2.1.2016.

Prihvaćen / Accepted: 24.2.2016.

Dostupno online / Available online: 10.9.2016.

# Utjecaj stanja višetravnih kolnika na promet osobnih vozila

## Autori:



Izv.prof.dr.sc. **Ahmed Mohamed Semeida**, dipl.ing.građ.  
Sveučilište Port-Said, Egipat  
Građevinski fakultet  
[asmeeda@eng.psu.edu.eg](mailto:asmeeda@eng.psu.edu.eg)



Prof.dr.sc. **Mohamed El-Shabrawy**, dipl.ing.građ.  
Sveučilište El-Mansoura, Egipat  
Građevinski fakultet  
[mshabrawy@mans.edu.eg](mailto:mshabrawy@mans.edu.eg)

Prethodno priopćenje

**Ahmed Mohamed Semeida, Mohamed El-Shabrawy**

## Utjecaj stanja višetravnih kolnika na promet osobnih vozila

U ovom radu istražen je utjecaj stanja kolnika, ravnosti kolnika i uzdužnog nagiba na iznos operativne brzine osobnih vozila ( $V_{85}$ ) na višetravnim cestama. Stanje kolnika opisano je pomoću indeksa stanja kolnika, dok je ravnost kolnika opisana međunarodnim indeksom ravnosti. Podaci za ispitivanje prikupljeni su na 67 dionica ceste u pravcu, a u analizi tih dionica primijenjena su tri različita postupka modeliranja: linearna regresija, generalizirano linearno modeliranje te umjetna neuronska mreža. Rezultati istraživanja su pokazali da je primjena umjetne neuronske mreže najbolja za procjenu operativne brzine  $V_{85}$  s obzirom na glavne statističke parametre.

### Ključne riječi:

višetravna cesta, ravnost kolnika, stanje kolnika, operativna brzina, neuronska mreža

Scientific paper – Preliminary report

**Ahmed Mohamed Semeida, Mohamed El-Shabrawy**

## Impact of pavement condition on passenger car traffic

The present paper explores the influence of pavement condition, roughness, and longitudinal grade on the operating speed ( $V_{85}$ ) of passenger car traffic at multi-lane roads. The pavement condition is described as a pavement condition index, while pavement roughness is expressed as an international roughness index. The necessary data are collected at 67 tangent sections and the following three modelling approaches are adopted for analysis: linear regression, multiple regression analysis, and artificial neural network. The obtained results show that the artificial neural network modelling approach is the best one for estimating the operating speed  $V_{85}$  in terms of main statistical parameters.

### Ključne riječi:

multi-lane road, roughness, pavement condition, operating speed, neural network

Vorherige Mitteilung

**Ahmed Mohamed Semeida, Mohamed El-Shabrawy**

## Einfluss mehrspuriger Fahrbahnen auf den Verkehr von Personenwagen

In dieser Arbeit wird der Einfluss von Fahrbahnzustand, sowie Ebenheit und Neigung in Längsrichtung auf die operative Geschwindigkeit von Personenwagen ( $V_{85}$ ) auf mehrspurigen Straßen untersucht. Der Fahrbahnzustand wird mit dem Zustandsindex beschrieben und die Ebenheit mit dem internationalen Ebenheitsindex. Für die Untersuchungen benötigte Daten wurden auf 67 geraden Fahrbahnabschnitten verzeichnet und aufgrund drei verschiedener Modellierungsverfahren analysiert: mittels linearer und multipler Regression, sowie mit künstlichen neuronalen Netzen. Die Resultate haben gezeigt, dass mit künstlichen neuronalen Netzen die operative Geschwindigkeit  $V_{85}$  in Bezug auf die wichtigsten statistischen Parameter am besten beurteilt werden kann.

### Ključne riječi:

mehrsprungige Straßen, Ebenheit, Fahrbahnzustand, operative Geschwindigkeit, neuronale Netze

## 1. Uvod

Stanje kolnika i brzina vožnje faktori su koji značajno utječu na učinkovitost prometnog sustava. Izvangradske višetrake ceste čine bitan dio cestovne prometne mreže te bi stoga održavanje kolnika na takvim prometnicama trebalo biti prioritet uprava za ceste. Brzina vožnje važan je parametar kojim su određeni sigurnost, vrijeme, udobnost, praktičnost i isplativost vožnje. Osim toga, brzina je važan pokazatelj očekivanog stanja kolnika i ravnosti njegove površine.

Ovo istraživanje bavi se ispitivanjem utjecaja ravnosti površine kolnika, stanja kolnika i uzdužnog nagiba na iznos operativne brzine osobnih vozila. Ravnost kolnika izražena je međunarodnim indeksom ravnosti (eng. *International roughness indeks - IRI*), dok je stanje kolnika izraženo indeksom stanja kolnika (eng. *pavement condition index - PCI*). Ovi se parametri neće detaljno opisivati u radu.

Prvi dio istraživanja odnosi se na definiranje odnosa između brzine i stanja kolnika primjenom tradicionalnih postupaka kao što su linearna regresija i generalizirano linearno modeliranje (eng. *generalized linear modeling - GLM*). To se provodi s ciljem predviđanja operativne brzine pod uvjetima slobodnog prometnog toka na cestama s više prometnih trakova, kakve se nalaze u Egiptu. U drugom dijelu istraživanja za predviđanje operativne brzine primijenjena je napredna metoda modeliranja umjetnom neuronskom mrežom (eng. *artificial neural network - ANN*). Modeliranje odnosa operativne brzine i stanja kolnika pomoću ANN modela drugi je aspekt ovoga rada.

U ovom istraživanju određeni su empirijski matematički odnosi između operativne brzine i stanja kolnika (stanje kolnika, ravnost vozne površine i uzdužni nagib) primjenom tradicionalnih statističkih modela (linearnih i GLM) te modela umjetne neuronske mreže (ANN). Podatke o kolniku potrebne za razvoj modela ustupila je Uprava za ceste i mostove te cestovni promet (eng. *General Authority of Roads & Bridges and Land Transport - GARBLT*) [1], koja prikuplja podatke na četiri prometnice promatrane u ovome radu. Navedena tri modela ocijenjena su za dionice s dva prometna traka, dionice s tri prometna traka te za kombinirane podatke. Na temelju statističkih parametara provedena je usporedba dviju metoda modeliranja.

## 2. Pregled literature

Ovo istraživanje promatra samo uvjete slobodnog prometnog toka iz razloga jer u uvjetima nestabilnog prometnog toka, u kojima interakcije među vozilima značajno utječu na brzinu vožnje, nije moguće odrediti stvarnu vezu između stanja kolnika i brzine vožnje. Drugim riječima, u uvjetima nestabilnog prometnog toka vozači se po dobrom kolniku ne kreću istom brzinom kojom bi se kretali u uvjetima slobodnog prometnog toka.

Homburger i dr. [2] u radu *Osnove prometnog inženjerstva* (eng. *Fundamentals of Traffic Engineering*) definirali su slobodni prometni tok pomoću minimalnog vremenskog razmaka između

vozila u iznosu od 4 sekunde. Fitzpatrick i dr. [3] zaključuju da bi se uvjetima slobodnog prometnog toka trebao smatrati vremenski razmak između vozila jednak i veći od 5 sekundi.

Prema standardu za projektiranje i planiranje cesta (eng. *Highway Capacity Manual - HCM*) iz 2010. godine [4], na brzinu slobodnog prometnog toka dionice autoceste utječu: širina prometnog traka, bočna zaštitna širina te gustoća spojnih rampi. Navedeno upućuje na to da istraživači koji su razvijali ovaj model nisu u obzir uzeli ravnost, stanje kolnika i uzdužni nagib.

Na temelju istraživanja provedenog na 72 ispitne dionice u blizini Ontaria u Kanadi razvili su Karan i dr. [5] regresijski model brzine ceste. Varijable korištene u tom modelu uključivale su indeks udobnosti vožnje (eng. *riding comfort index - RCI*), indeks ravnosti kolnika (IRI), ukupni kapacitet ceste, količinu prometa te ograničenje brzine vožnje. Autori su zaključili da je stanje kolnika značajno utjecalo na brzinu vožnje motornih vozila. U slučaju kada bi se indeks IRI povećao s 1 na 2 m/km, a sve druge varijable ostale nepromijenjene, brzina bi se smanjila za otprilike 3,11 km/h.

Watanatada i dr. [6] razvili su model brzine na temelju pristupa koji se naziva model ograničenja brzine (eng. *Limiting Speed Model*). U tom modelu ravnost kolnika glavni je faktor koji utječe na ograničenje brzine ravnosti (eng. *Roughness Limiting Speed*). Indeks IRI pretvoren je u maksimalnu brzinu kojom se vozilo može kretati pri određenoj razini ravnosti pomoću maksimalne prosječne ispravljene brzine (eng. *maximum average rectified velocity - ARVMAX*), sadržane u empirijskoj jednadžbi (1), [6]:

$$\text{Ograničenje brzine ravnosti} = \frac{ARVMAX [km/h]}{(a_0 \cdot IRI)} \quad [km/h] \quad (1)$$

gdje je koefijent  $a_0 = 1,15$  (prema HDM-4).

Autori su zaključili da je ravnost kolnika ograničavajući faktor tek u slučaju kada vrijednost indeksa IRI pređe 6 m/km. To se stanje rijetko javlja na suvremenim cestovnim mrežama u SAD-u. Ovaj rezultat ponovno upućuje na to da ravnost kolnika nema značajan utjecaj na vrijednost brzine slobodnog prometnog toka.

Elkins i Semrau [7] su, na temelju podataka prikupljenih u Brazilu te analiza i istraživanja provedenih u SAD-u, predstavili modele brzina za automobile i kamione u SAD-u. Cox [8] je na temelju studije iz Australije, koja je pokazala da ravnost kolnika utječe na brzinu vožnje samo pri vrijednostima indeksa IRI većim od 5 m/km, zaključio da na glatkim kolnicima ravnost ne utječe na brzinu vožnje. Takvi su rezultati otvorili pitanje utječe li ravnost kolnika uopće na brzinu vožnje.

Chandra [9] je na primjeru dvotračne ceste istraživao odnos između ravnosti kolnika, brzine vožnje i kapaciteta ceste, na način da je postavljao jednostavan linearni odnos između ravnosti kolnika i brzine slobodnog prometnog toka. Istraživanja je provodio zasebno za osobna te zasebno za teretna vozila. Uzorci indeksa IRI prikupljeni u ovom istraživanju iznosili su od 2 do 7 m/km. Autor je zaključio da ravnost kolnika negativno utječe na brzinu slobodnog prometnog toka te da je ravnost značajna varijabla u tom odnosu.

Wang i dr. [10] su brzinu slobodnog prometnog toka na autocestama u Kaliforniji određivali pomoću modela linearne regresije. Varijable korištene u tom istraživanju uključivale su ukupan broj prometnih trakova, dan u tjednu, regiju (pokrajina Caltrans), cijenu goriva te ravnost kolnika u obliku indeksa IRI. Za izradu modela korišteni su podaci o kalifornijskoj prometnoj mreži od 2000. do 2011. godine. Devedeset posto zapisa imalo je vrijednost indeksa IRI jednaku ili manju od 3 m/km, te promjenu indeksa IRI jednaku ili manju od 2 m/km. Rezultati istraživanja pokazali su da ravnost kolnika ima vrlo mali utjecaj na brzinu slobodnog prometnog toka. Promjena indeksa IRI u iznosu od 1 m/km rezultirala je promjenom prosječne brzine slobodnog prometnog toka od 0,48 do 0,64 km/h.

Ilić [11] je na temelju detaljnog pregleda literature, koja je obrađivala odnos ravnosti kolnika i brzine vožnje, zaključio da na cestama na kojima je indeks IRI manji od 5 m/km, što je uglavnom karakteristika cesta u razvijenim državama, ravnost kolnika nema značajan utjecaj na brzinu vožnje.

U Egiptu nažalost, zbog nedostatka podataka, dosada nije provedeno niti jedno slično istraživanje. Egipat je zemlja u razvoju čiji prometni sustav sadrži mnogo problema, od kojih je jedan i loše stanje kolnika. Loše stanje kolnika nepovoljno utječe na brzinu vožnje te proces manevriranja. Kao posljedica, stvaraju se kolone te dolazi do učestalih prometnih nesreća te zagađenja okoliša. S obzirom na sve navedeno, veoma je važno objasniti i analizirati odnos između brzine vožnje i stanja kolnika. Poznavanje tog odnosa veoma bi pomoglo radu uprava za ceste u Egiptu.

### 3. Ispitne dionice i podaci s terena

#### 3.1. Ispitne dionice

Analizom je obuhvaćeno 67 dionica u pravcu duljine 100 m koje se nalaze na četiri izvangradske višetrakčne prometnice u Egiptu: 39 dionica se nalazi na dvotračnim cestama, a preostalih 28 dionica na trotračnim cestama. Sve dionice imaju iste širine prometnih trakova i razdjelnih pojasa te iste sigurnosne bočne odmake. Utjecaj tih parametara na iznos operativne brzine  $V_{85}$  se stoga može zanemariti. Istraživanjem su obuhvaćene lokalne ceste Kairo-Aleksandrija (eng. *Cairo-Alexandria Agricultural Highway - CAA*) i Tanta-Damietta (eng. *Tanta-Damietta Agricultural Highway - TDA*) te ceste kroz pustinju Kairo-Aleksandrija (eng. *Cairo-Alexandria Desert Highway - CAD*) i Kairo-Ismailia (eng.

*Cairo-Ismailia Desert Highway - CID*). Na slici 1. prikazan je položaj navedenih prometnica u egipatskoj prometnoj mreži.



Slika 1. Položaj višetrakčnih cesta u egipatskoj prometnoj mreži

#### 3.2. Podaci o kolniku

Podaci o kolniku ključne su nezavisne varijable u analizi. Ti podaci uključuju uzdužni nagib kolnika  $G$ , indeks ravnosti IRI i indeks stanja kolnika PCI. Nagib kolnika  $G$  na svim dionicama izmjerio je Abdalla [12]. PCI indeks je izračunan pomoću sustava Micro PAVER u kojem se stanje kolnika ocjenjuje numeričkim vrijednostima u rasponu od 0 do 100. Ocjena 0 označava nezadovoljavajuće stanje kolnika, a ocjena 100 odlično stanje kolnika. Izračun PCI indeksa temelji se na operativnom stanju površine kolnika, jer ono upućuje na potencijalno propadanje kolnika te potrebu za održavanjem i popravcima. PCI indeks na svim promatranim dionicama izračunan je pomoću sustava Micro PAVER (PAVER verzija 5.3.4).

Ocjena ravnosti površine kolnika provedena je računanjem indeksa ravnosti IRI. Ravnost kolnika mjerena je uređajem *Bump Integrator* (verzija ROMDAS). Podaci prikupljeni na terenu obrađeni su u računalnom programu ROMDAS, koji računa indeks IRI po dionicama. Opremu za ispitivanje je osigurao GARBLT [1]. Popis korištenih varijabli, njihovi simboli i rezultati statističke analize prikazani su u tablici 1.

#### 3.3. Podaci o brzini vožnje

Podaci o brzini vožnje osobnih vozila ključna su zavisna varijabla u analizi. Ovaj rad ne razmatra utjecaj prometnog toka na brzinu

Tablica 1. Simboli i rezultati statističke analize ispitivanih varijabli

Varijable	Simbol	Maks.	Min.	Prosječna vrijednost	Standardno odstupanje
Uzdužni nagib [%]	G	4,95	-5,78	2,05	2,22
Indeks stanja kolnika	PCI	98	25	55,91	24,23
Internacionalni indeks ravnosti IRI	IRI	20,98	0,78	6,53	5,09
Broj prometnih trakova u jednom smjeru	NL	3	2	-	-

vožnje, nego utjecaj ravnosti kolnika, stanja kolnika i uzdužnog nagiba na iznos operativne brzine. Osobnim vozilima u ovom istraživanju smatraju se vozila taksija, osobni automobili, kombiji te SUV vozila. Podaci o brzini vožnje prikupljeni su pomoću laserskog pištolja (verzija LASER 500 s točnošću  $\pm 1$  km/h), postavljenog na nekoliko skrivenih lokacija uz cestu duž svake dionice kako ga vozači ne bi primijetili, Adballa [12]. Vremenski

razmak između vozila, koja su se kretala u uvjetima slobodnog prometnog toka, iznosio je najmanje 5 sekundi. Na svakom mjernom mjestu prikupljeno je između 100 i 160 podataka o brzini, što je u konačnici rezultiralo s 8700 zabilježenih brzina. Podaci su prikupljeni radnim danima i u dnevnim satima. Tijekom prikupljanja podataka vrijeme je bilo vedro, a kolnici suhi i u dobrom stanju.

Tablica 2. Vrijednosti operativnih brzina osobnih vozila ( $V_{85C}$ ) po dionicama (napomena: oznaka C dolazi od engleske riječi car)

Oznaka ceste	Broj presjeka	Broj trakova u jednom smjeru	$V_{85C}$ [km/h]	Oznaka ceste	Broj presjeka	Broj trakova u jednom smjeru	$V_{85C}$ [km/h]
CAA	1	2	52,25	CID	35	2	106,62
CAA	2	2	73,83	CAD	36	3	98,3
CAA	3	3	66,45	CAD	37	3	95,55
CAA	4	3	74,2	CAD	38	3	92,5
CAA	5	3	44	CAD	39	3	93,63
CAA	6	3	92,32	CAD	40	2	67,36
CAA	7	3	66,42	CAD	41	3	111,9
CAA	8	2	49,59	CAD	42	2	68,35
CAA	9	3	67,23	CAD	43	3	110,27
CAA	10	2	58,03	CAD	44	2	73,13
CAA	11	2	50,15	CAD	45	3	109,66
CAA	12	2	60,7	CAD	46	3	91,13
CAA	13	2	83,75	CAD	47	3	40,2
CAA	14	2	83,23	CAD	48	3	85,33
CAA	15	3	66,73	TDA	49	2	71,61
CAA	16	3	35,7	TDA	50	2	73,59
CAA	17	3	96,26	TDA	51	2	53,622
CAA	18	2	76,21	TDA	52	2	72,65
CAA	19	2	77,25	TDA	53	2	98,75
CAA	20	2	56,7	TDA	54	2	93,73
CAA	21	2	28,53	TDA	55	2	94,73
CID	22	2	71,89	TDA	56	2	85,68
CID	23	3	39,08	TDA	57	2	102,68
CID	24	3	100	TDA	58	2	91,82
CID	25	2	62,5	TDA	59	2	101,15
CID	26	3	77,5	TDA	60	2	97,02
CID	27	2	57,25	TDA	61	2	94,64
CID	28	3	95	TDA	62	2	104,23
CID	29	3	68,33	TDA	63	2	95,24
CID	30	3	44,09	TDA	64	2	94,82
CID	31	3	38,13	TDA	65	2	93,28
CID	32	3	56,88	TDA	66	2	102,99
CID	33	2	39,92	TDA	67	2	87,65
CID	34	3	93				

Općenito, da bi se osigurala valjanost Paersonove korelacije, svaki skup odabranih podataka mora imati normalnu distribuciju. Primjenom Kolmogorov-Smirnovog testa zaključeno je da normalna distribucija podataka ne može biti odbačena pri razini pouzdanosti od 95%. Zahtijevana veličina uzorka operativne brzine ( $V_{85}$ ) određena je primjenom poznate statističke jednadžbe (2):

$$N = \frac{\sigma^2 K^2 (2 + u^2)}{2E^2} \quad (2)$$

gdje je:

$N$  - najmanji broj uzorka

$\sigma$  - procijenjena standardna devijacija uzorka

$K$  - konstanta koja odgovara traženoj razini pouzdanosti od 95 % (1,96)

$E$  - dopuštena pogreška u procjeni prosječne brzine ( $\pm 2$  km/h)

$u$  - konstanta koja odgovara traženoj 85 % brzini (1,04).

Vrijednosti operativnih brzina osobnih vozila ( $V_{85C}$ ) po dionicama prikazane su u tablici 2.

## 4. Metodologija

Vrijednost operativne brzine  $V_{85}$  u ovom istraživanju određena je primjenom tradicionalnog linearnog i generalizirano linearnog (GLM postupka) te nekonvencionalnog ANN postupka. Mnogi istraživači došli su do zaključka da ANN postupak, zbog normalnosti reziduala i neovisnosti o predviđenoj varijabli, daje bolji model u slučaju boljih predviđanja nižih vrijednosti operativne brzine  $V_{85}$ . Nekoliko istraživača zaključilo je da je učinkovitost ANN postupka veća od učinkovitosti tradicionalnih postupaka. Prednost ANN postupka u odnosu na tradicionalne postupke je ta što ANN može direktno uzeti u obzir bilo koji nelinearni odnos između zavisnih i svake nezavisne varijable. Druga prednost je ta što je ANN postupak brz i fleksibilan. I konačno, ANN model je jednostavan za uporabu.

### 4.1. Tradicionalni postupci modeliranja

#### 4.1.1. Linearna regresija

Matematički oblik linearne regresije prikazuje se pomoću sljedeće jednadžbe:

$$Y = \beta_0 + \sum_{i=1}^n \beta_i x_i \quad (3)$$

gdje je:

$Y$  -  $V_{85}$  na svakoj dionici

$x_i$  - varijabla od 1 do  $n$

$\beta_0$  - konstanta regresije

$\beta_i$  - koeficijent regresije.

Stupnjevita regresijska analiza primjenjuje se pri odabiru statistički najznačajnijih nezavisnih varijabli sa zavisnom varijablom u jednom modelu. Ta analiza zadržava samo statistički značajne

izraze u modelu. Odabrani model imat će najmanji broj nezavisnih varijabli, minimalnu normu beskonačnog vektora pogreške ( $\|\delta\|$ ), korijen srednje kvadratne prognostičke pogreške (eng. *Root Mean Squared Error* - RMSE) te najveću  $R^2$  vrijednost.

#### 4.1.2. Generalizirano linearno modeliranje (GLM)

U ovom postupku matematički oblik uključuje svaku nezavisnu varijablu zasebno. Rješavanjem prirodnog logaritma uspostavlja se snažan odnos između nezavisnih varijabli i operativne brzine  $V_{85}$ . Na taj se način određuje utjecaj svake nezavisne varijable na iznos operativne brzine  $V_{85}$ . Pri modeliranju podataka primijenjena je normalna logaritamska distribucija. Taj oblik prikazan je u jednadžbi (4) prema Varagouliju i dr. [13]:

$$V_{85} = \exp(\beta_0) \times X_1^{\beta_1} \times \dots \times X_n^{\beta_n} \quad (4)$$

gdje je:

$X_n$  - varijabla od 1 do  $n$

$\beta_0$  - konstanta regresije

$\beta_n$  - koeficijent regresije.

Navedeni oblik rješava se pomoću općeg linearnog modela PROC GENMOD u statističkom računalnom programu SAS [14]. Računalni program SAS za procjenu koeficijenata regresije, standardnih pogrešaka, Waldovog hi kvadrat testa te p-vrijednosti koristi tehniku maksimalne izglednosti. Odabrani model ima minimum  $\|\delta\|$ , RMSE, i najveću  $R^2$  vrijednost.

#### 4.1.3. Multikolinearnost

Multikolinearnost je čest problem koji se javlja prilikom procjene linearnih i GLM modela. Do ove pojave dolazi uslijed čvrste veze između prediktorskih varijabli koja vodi do nepouzdanosti i nestabilnih procjena koeficijenata regresije. Najprimjenjiviji faktor za dijagnostiku u multikolinearnosti je faktor inflacije varijacije (eng. *variance inflation factor* - VIF) koji procjenjuje koliko je varijacija koeficijenta "precijenjena" zbog linearne ovisnosti o drugim prediktorima. Vrijednost faktora VIF 1,8 upućuje na to da je taj prediktor u potpunosti nepovezan s drugim prediktorima. Općenito, vrijednost faktora VIF ne bi trebala biti veća od 2,50, što odgovara vrijednosti  $R^2 = 0,6$ , Alison [15].

### 4.2. Primjena umjetne neuronske mreže

Modeliranje pomoću umjetne neuronske mreže (ANN) sastoji se od tri sloja: ulaznog, skrivenog i izlaznog. Statistički gledano, ulazni sloj sadrži nezavisne varijable, a izlazni sloj sadrži zavisne varijable. ANN postupak obično započinje s nasumičnim težinama za sve njihove neurone. Kada je postignuta zadovoljavajuća razina izvedbe, ispitivanje je završeno, a mreža koristi težine kako bi se donijela odluka.

Semeida [16] je na temelju svojih istraživanja zaključio da modeli više-slojne perceptronske neuralne mreže (eng. *multi-*



layer perceptron neural network - MLP) imaju najbolja svojstva. Ta se mreža često koristi i u inženjerskoj praksi jer sadrži mnogo algoritama za učenje.

Jedan od često korištenih algoritama za učenje u ANN modeliranju je algoritam propagacije unatrag (eng. *back propagation algorithm* - BP); navedeni algoritam je primijenjen i u ovom istraživanju (NeuroSolutions7), [17]. U tom algoritmu cjelokupni skup podataka dijeli se na skup probnih i skup testnih podataka. Prema literaturi, skup probnih podataka trebao bi činiti 70 do 90 % svih podataka, dok bi skup testnih podataka trebao činiti 10 do 30% svih podataka. Svojstva modela za skup testnih podataka, skup probnih podataka te za cjelokupni skup podataka su RMSE,  $\|\delta\|$ , i  $R^2$ .

Mnoga su ispitivanja provedena kako bi se odredio odgovarajući postotak probnih i testnih podataka koji rezultira najboljim svojstvima modela operativnih brzina. Nepodudaranje podataka može se spriječiti nasumičnom raspodjelom svih dionica prije učenja mreže da postigne najbolja svojstva probnih i testnih podataka. Testni podaci moraju biti jednako pouzdani kao i probni podaci (vrijednost  $R^2$  ne smije biti manja od 0,7), Tarefder i dr. [18].

## 5. Analize, rezultati i rasprave

### 5.1. Rezultati modela linearne regresije

Stupnjevitoj regresijskoj analizi provedenoj pomoću programskog paketa SPSS, za dionice s dva i tri prometna traka te za kombinirane podatke definirane su tri najbolja modela koja su statistički značajna s obzirom na brzinu  $V_{85}C$ , izrazi (5), (6) i (7). U navedenim modelima sve varijable su bile značajne pri razini pouzdanosti 5% ( $P$ -vrijednost  $< 0,05$ ). Mnogi modeli bili su isključeni iz analize ili zato što nisu bili značajni s obzirom na brzinu  $V_{85}C$  ili zato što su sadržavali multikolinearne prediktorske varijable.

$$V_{85}C \text{ (2-trake)} = 87,86 - 2,18 \cdot IRI + 0,17 \cdot PCI \quad (5)$$

(gdje je  $R^2_{adj} = 0,91$ ,  $RMSE = 5,74$ ,  $\|\delta\| = 0,14$ )

Vrijednost faktora VIF za indeks IRI i PCI indeks iznosi 1,562, što bi značilo da nema opasnosti od multikolinearnosti (vrijednost je manja od 2,5), Allison [16].

$$V_{85}C \text{ (3-trake)} = 96,07 - 4,11 \cdot IRI + 0,15 \cdot PCI \quad (6)$$

(gdje je  $R^2_{adj} = 0,82$ ,  $RMSE = 8,54$ ,  $\|\delta\| = 0,2$ )

Vrijednost faktora VIF za indeks IRI i PCI indeks iznosi 1,103.

$$V_{85}C \text{ (kombinirana)} = 43,93 - 2,02 \cdot IRI + 20 \cdot PCI \quad (7)$$

(gdje je  $R^2_{adj} = 0,87$ ,  $RMSE = 10,07$ ,  $\|\delta\| = 0,2$ )

Vrijednost faktora VIF za indeks IRI i NL iznosi 1,689.

Ispitivanje provedeno na modelima dionica s dva i tri prometna traka pokazalo je da se brzina  $V_{85}C$  smanjuje s porastom

vrijednosti indeksa IRI. Razlog tomu je negativni predznak koeficijenta koji se nalazi uz indeks IRI. Povećanje neravnosti uzrokuje značajne nepravilnosti na površini kolnika. Prilikom vožnje po takvim neravnim površinama vozači osjećaju vibracije zbog kojih smanjuju brzinu vožnje. Pozitivan predznak koeficijenta koji se nalazi uz PCI indeks rezultira povećanjem brzine  $V_{85}C$  s porastom PCI indeksa. Kolnici koji sadrže manje nepravilnosti i koji se nalaze u boljem stanju potiču vozače na vožnju većim brzinama. Takvi rezultati moraju biti uvjerljivi. Za kombinirane modele je zaključeno da indeks IRI utječe na smanjenje brzine vožnje te da povećanje broja prometnih trakova utječe na prirast brzine. Ti su rezultati točni, ali trebaju biti pouzdaniji kako bi odgovarali statističkim parametrima.

### 5.2. Rezultati GLM postupka

Primjenom GLM postupka PROC GENMOD u računalnom programu za statistiku SAS [15], za dionice s dva i tri prometna traka te za kombinirane podatke definirane su tri najbolja modela koja su statistički značajna s obzirom na brzinu  $V_{85}C$ , izrazi (8), (9) i (10).

$$V_{85}C \text{ (2-trake)} = \exp(4,91) \cdot IRI^{-0,32} \quad (8)$$

(gdje je,  $R^2_{adj} = 0,92$ ,  $RMSE = 5,58$ ,  $\|\delta\| = 0,2$ )

$$V_{85}C \text{ (3-trake)} = \exp(4,87) \cdot IRI^{-0,35} \quad (9)$$

(gdje je,  $R^2_{adj} = 0,92$ ,  $RMSE = 8,96$ ,  $\|\delta\| = 0,15$ )


$$V_{85}C \text{ (kombinirana)} = \exp(4,44) \cdot IRI^{-0,25} \quad (10)$$

(gdje je,  $R^2_{adj} = 0,84$ ,  $RMSE = 26,89$ ,  $\|\delta\| = 0,28$ )

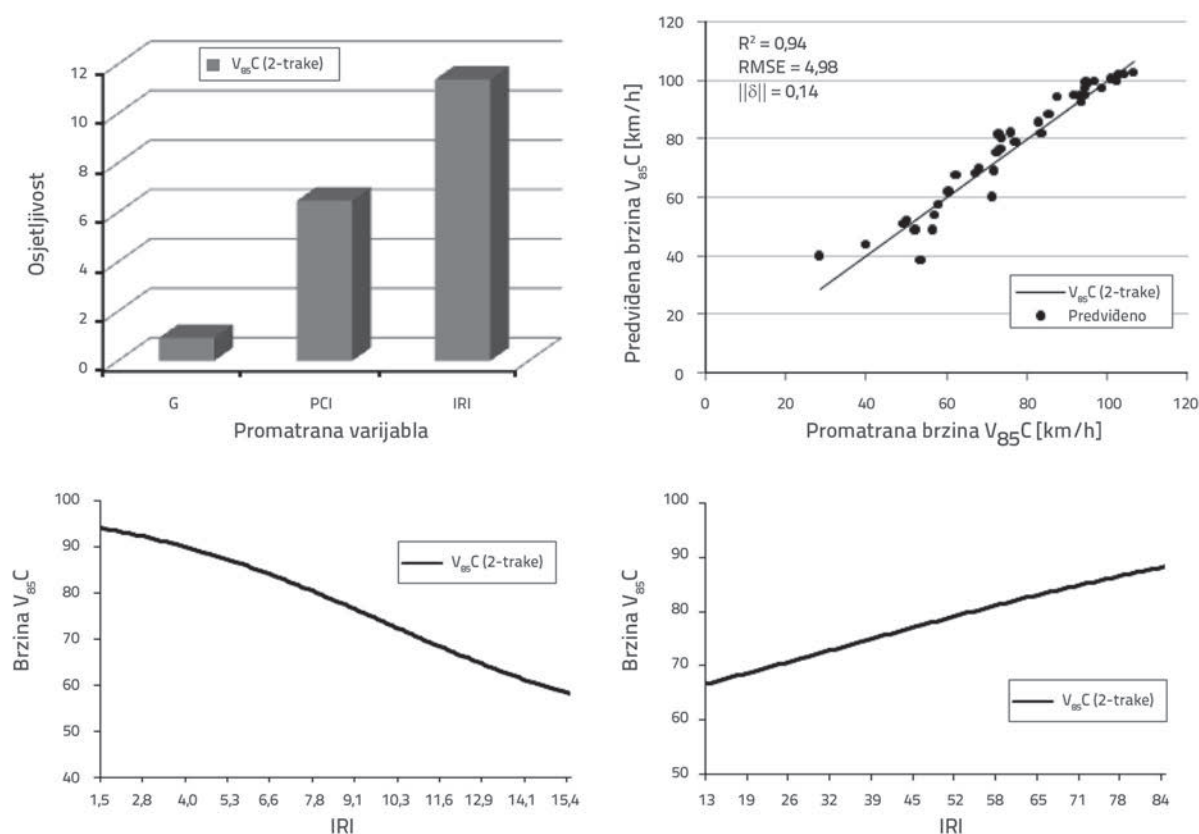
U ta tri modela indeks IRI znatno više utječe na smanjenje brzine vožnje od drugih varijabli. U kombiniranom modelu broj prometnih trakova ima umjeren učinak na prirast brzine vožnje. Takvi su rezultati logični, no nisu dovoljno pouzdani i točni.

### 5.3. Rezultati ANN modela

Za mrežu 39 dionica s dva prometna traka, tri su nezavisne varijable (IRI, PCI i G) postavljene u ulazni sloj, a jedna tražena varijabla  $V_{85}C$  u izlazni sloj, prilikom čega je korišten jedan skriveni sloj. Broj elemenata u skrivenom sloju jednak je polovini ukupnog broja neurona u ulaznom i izlaznom sloju (dva elementa za obradu), što je uobičajena praksa prilikom provođenja ovog postupka. Izgled ANN modela prikazan je na slici 2.





Slika 2. Prikaz MLP mreže za  $V_{85}C$  model (MLP - model višeslojne perceptronske neuralne mreže)

Slika 3. Validacija i analiza osjetljivosti modela brzine  $V_{85}C$  (2-traka) primjenom ANN postupka

Prema Semeiri [19, 20], za brzo rješavanje problema potrebno je primjenjivati pravila momentuma i provesti odgovarajući broj iteracija = 5000. U ovom istraživanju provedena su mnoga ispitivanja kako bi se odredio postotak između probnih i testnih podataka koji daje najbolja svojstva modela. Kao najbolje rješenje pokazalo se ono u kojem su probni podaci sadržavali 32 dionice (82 % svih dionica), a testni podaci 7 dionica (18 % svih dionica). Kako bi se izmjerila važnost svake varijable, izračunan je opći utjecaj (osjetljivost na prosječnu vrijednost ili standardnu devijaciju) na temelju istreniranih težina ANN modela. Ako je osjetljivost na prosječnu vrijednost određene nezavisne varijable veća od osjetljivosti drugih varijabli, onda je utjecaj te varijable na zavisnu varijablu ( $V_{85}C$ ) veći od utjecaja drugih varijabli. Slika

3. prikazuje osjetljivost svake varijable u odabranom modelu. Zaključeno je da na iznos brzine  $V_{85}C$  (2-traka) najviše utječe indeks IRI, a zatim PCI indeks. Na istoj slici prikazani su odnosi između svake efektivne ulazne varijable i brzine  $V_{85}C$  (2-traka), koji upućuju na to da se brzina  $V_{85}C$  smanjuje s porastom indeksa IRI, odnosno povećava s povećanjem PCI indeksa. Ovi rezultati su točniji, pouzdaniji i logičniji od rezultata tradicionalnih modela. Za mrežu dionica s tri prometna traka u najboljem modelu sve dionice su podijeljene na 23 probne (82 %) i 5 testnih dionica (18 %). Slika 4 prikazuje osjetljivost svake varijable u odabranom modelu. Zaključeno je da na brzinu  $V_{85}C$  (3-traka) utječe samo indeks IRI. Na istoj slici je prikazan i odnos između indeksa IRI i brzine  $V_{85}C$  (3-traka). Zaključeno je da se brzina  $V_{85}C$  (3-traka)

Slika 4. Validacija i analiza osjetljivosti modela brzine  $V_{85}C$  (3-traka) primjenom ANN postupka

Slika 5. Validacija i analiza osjetljivosti modela brzine  $V_{85}C$  (kombinirana) primjenom ANN postupkaTablica 3. Svojstva najboljih ispitivanja ANN  $V_{85}C$  modela

Model	Svojstva	Probni uzorci	Testni uzorci	Cijeli model
$V_{85}C$ (2-traka)	$R^2$	0,96	0,93	0,94
	RMSE	4,15	7,72	4,98
	$\ \delta\ $	0,11	0,15	0,14
$V_{85}C$ (3-traka)	$R^2$	0,99	0,93	0,97
	RMSE	2,77	8,14	4,26
	$\ \delta\ $	0,05	0,13	0,12
$V_{85}C$ (kombinirana)	$R^2$	0,98	0,92	0,97
	RMSE	3,12	6,89	3,99
	$\ \delta\ $	0,09	0,15	0,14

smanjuje s povećanjem indeksa IRI. Ovi rezultati su pouzdaniji od rezultata tradicionalnih modela.

Za kombiniranu mrežu četiri su nezavisne varijable (IRI, PCI, NL i G) postavljene u ulazni sloj, a jedna tražena varijabla  $V_{85}C$  (kombinirana) u izlazni sloj, prilikom čega je korišten jedan skriveni sloj za svih 67 zapažanja. U najboljem su modelu sve dionice podijeljene na 56 probnih (84 %) i 11 testnih (16 %). Slika 5. prikazuje osjetljivost svake varijable u odabranom modelu. Zaključeno je da na brzinu  $V_{85}C$  (kombinirana) utječe samo indeks IRI. Na istoj slici prikazan je i odnos između indeksa IRI i brzine  $V_{85}C$  (kombinirana). Uočeno je da se brzina  $V_{85}C$  (kombinirana) smanjuje s porastom vrijednosti indeksa IRI. Ovi rezultati su točniji i racionalniji od rezultata tradicionalnih modela.


Svojstva najboljeg ispitivanja za probni, testni te ukupni skup podataka za 3 ANN modela prikazana su u tablici 3.

## 5.4. Usporedba rezultata

Rezultati dobiveni odabranim postupcima modeliranja, izraženi pomoću parametara  $R^2$ , RMSE, i  $\|\delta\|$ , prikazani su na slici 6. Na temelju usporedbe rezultata može se zaključiti da se u slučaju sva tri modela (za dionice s dva prometna traka, za dionice s tri prometna traka te kombinirane podatke) ANN postupak pokazao boljim od linearne regresije i GLM postupka. S obzirom na navedeno, u budućim ispitivanjima preporučuje se primjena ANN postupka.

## 6. Zaključak

Cilj ovog istraživanja bio je odrediti utjecaj stanja kolnika, ravnosti i uzdužnog nagiba na iznos operativne brzine  $V_{85}$  na 67 dionica u pravcu, raspoređenih na četiri državne ceste u Egiptu. U istraživanju su korištena i ocijenjena tri modela



Slika 6. Usporedba rezultata linearne regresije, GLM-a i ANN postupka



za dionice s dva prometna traka (39 dionica) i s tri prometna traka (28 dionica) te za kombinirane podatke. Primijenjena su dva postupka modeliranja. Prvi postupak je tradicionalan i obuhvaćao je linearnu regresiju i GLM, dok je drugi postupak nekonvencionalan i obuhvaćao je ANN analizu. Zaključeno je sljedeće:

1. ANN postupak daje bolje, pouzdanije i dosljednije rezultate od linearne regresije i GLM postupka u pogledu izračunanih statističkih parametara.
2. Za model dionica s dva prometna traka parametar  $R^2$  dobiven ANN postupkom iznosi 0,94, linearnom regresijom 0,91 te GLM postupkom 0,92. Za model dionica s tri prometna traka parametar  $R^2$  dobiven ANN postupkom iznosi 0,97, linearnom regresijom 0,82 te GLM postupkom 0,92. Za kombinirani model parametar  $R^2$  dobiven ANN postupkom iznosi 0,97, linearnom regresijom 0,87 te GLM postupkom 0,84.
3. Rezultati najpovoljnijeg ANN-a za model dionica s dva prometna traka pokazali su da na brzinu  $V_{85C}$  najviše utječe indeks IRI, a zatim PCI indeks. Porast indeksa IRI za 1 m/km rezultira smanjenjem brzine  $V_{85C}$  za 2,6 km/h. Povećanje PCI indeksa za 10% rezultira povećanjem brzine  $V_{85C}$  za 3 km/h.
4. Rezultati najpovoljnijeg ANN-a za model dionica s tri prometna traka pokazali su da na brzinu  $V_{85C}$  značajno utječe samo indeks IRI. Povećanjem indeksa IRI za 1 km/h, brzina  $V_{85C}$  se smanjuje za 6 km/h.
5. Rezultati najpovoljnijeg ANN-a za kombinirane modele pokazali su da na brzinu  $V_{85C}$  utječe samo indeks IRI. Povećanjem indeksa IRI za 1 km/h, brzina  $V_{85C}$  se smanjuje za 4,5 km/h.
6. Za sve modele najznačajniji parametar je indeks IRI, osim za model dionica s dva prometna traka za koji je osim indeksa IRI

značajan i PCI indeks. Za model dionica s dva prometna traka korelacija između indeksa IRI i PCI indeksa iznosi -0,6, što upućuje na umjerenu vezu među njima; analiza osjetljivosti upućuje na tu vezu, ali je utjecaj indeksa IRI na operativnu brzinu još uvijek značajniji od utjecaja PCI indeksa. S druge strane, za modele dionica s tri prometna traka korelacija između indeksa IRI i PCI indeksa iznosi -0,4, a za kombinirane modele -0,3, što upućuje na slabu vezu među njima. Usprkos svemu navedenom, u oba je slučaja utjecaj PCI indeksa na operativnu brzinu zanemariv u odnosu na utjecaj indeksa IRI.

7. Rezultati brzine  $V_{85}$  vrlo su važni za kontrolu operativne brzine na višetrakčnim izvangradskim cestama u Egiptu. Prometna učinkovitost cesta može se poboljšati kontrolom brzine  $V_{85}$  pomoću indeksa IRI. Izvangradske višetrakčne ceste čine bitan dio cestovne prometne mreže te bi stoga održavanje kolnika na takvim prometnicama trebao bi biti prioritet uprava za ceste.

Zaključno, u budućim istraživanja trebao bi se promatrati utjecaj teških teretnih vozila, jer takva vozila značajno utječu na stanje kolnika. Osim toga, trebao bi se ispitati utjecaj oštećenja kolnika na kapacitet ceste.

## Zahvala

Autori zahvaljuju Upravi za ceste i mostove te cestovni promet (*General Authority of Roads & Bridges and Land Transport - GARBLT*) na ustupanju podataka za ispitivanje. Zahvaljuju i inženjeru Nassetu Abdalli s Odjela za građevinarstvo Tehničkog fakulteta Sveučilišta Al-Azhar na pomoći pri prikupljanju podataka na ispitnim dionicama.

## LITERATURA

- [1] General Authority of Roads, Bridges and Land Transport "GARBLT", Information System, El-Nasr St., Cairo, Egypt; 2009.
- [2] Homburger, W.S., Hall, J.W., Loutzenheiser, R.C., Reilly, W.R.: Spot Speed Studies (Chapter), In: *Fundamentals of traffic engineering*, Berkeley: Institute of Transportation Studies, University of California, pp. 6.1–6.9, 1996.
- [3] Fitzpatrick, K., Carlson, P., Brewer, M., Wooldridge, M.: Design Factors That Affect Driver Speed on Suburban Streets, *Journal of Transportation Research Record*, 1751, pp. 18–25, 2001.
- [4] Transportation Research Board (TRB). Highway Capacity Manual (HCM), first edn. Transportation Research Board, National Research Council, Washington, DC, 2010.
- [5] Karan, M.A., Kher, R., Haas, R.: Effects of Pavement Roughness on Vehicle Speeds, *Journal of Transportation Research Record*, Vol. 602, pp. 122–127, 1976.
- [6] Watanatada, T., Dhareshwar, A.M., Lima, P.R.S.R.: Vehicle Speeds and Operating Costs: Models for Road Planning and Management, *Book published by Johns Hopkins University Press*, Baltimore, MD, 1987.
- [7] Elkins, G.E., Semrau, J.: Development of Limiting Velocity Models for the Highway Performance Monitoring System, *Journal of Transportation Research Record*, 1195, pp. 138–141, 1988.
- [8] Cox, J.B.: Effect of Road Surface Condition on Vehicle Operating Costs in Australia: Literature Review and Fleet Database Analysis, *Report to AUSTROADS, Report published by Symonds Travers Morgan Pty Ltd*, Melbourne, Australia, 1991.
- [9] Chandra, S.: Effect of Road Roughness on Capacity of Two-Lane Roads, *Journal of Transportation Engineering-ASCE*, 130(3), pp. 360–364, 2004., [http://dx.doi.org/10.1061/\(ASCE\)0733-947X\(2004\)130:3\(360\)](http://dx.doi.org/10.1061/(ASCE)0733-947X(2004)130:3(360))
- [10] Wang, T., Harvey, J., Lea, J.D., Kim, C.: Impact of Pavement Roughness on Vehicle Free-Flow Speed, *Technical Memorandum: UCPRC-TM-2013-04*, University of California, Pavement Research Center, UC Davis, UC Berkeley, 2013.
- [11] Ilić, V.: Relationship between road roughness and vehicle speed, *International conference contemporary achievements in civil engineering 24*, pp. 491–497, Subotica, Serbia, 2015., <http://dx.doi.org/10.14415/konferencijaGFS 2015.062>

- [12] Abdalla, N.M.: Relationship between Traffic Flow Characteristics and Pavement Conditions on Roads in Egypt, M.Sc. Thesis, Department of civil Engineering, Faculty of Engineering, Al-Azhar University, Egypt, 2010.
- [13] Varagouli, A., Simos, T., Xeidakis, G.: Fitting a multiple regression line to travel demand forecasting: The case of the prefecture of Xanthi, Northern Greece, *Journal of Mathematics and Computer Modeling*, 42, pp. 817-836, 2005., <http://dx.doi.org10.1016/j.mcm.2005.09.010>
- [14] SAS Institute Inc. Version 9 of the SAS System for Windows. SAS, Cary, NC, USA, 2003.
- [15] Allison P. When Can You Safely Ignore Multicollinearity? Statistical horizon, 2012., <http://statisticalhorizons.com/multicollinearity>
- [16] Semeida, A.M.: Derivation of level of service by artificial neural networks at horizontal curves: a case study in Egypt, *Journal of European Transport Research Review*, 7 (2015) 1, pp. 1-12, <http://dx.doi.org10.1007/s12544-014-0152-2>
- [17] "NeuroSolutions 7", NeuroDimension, Inc. Gainesville, 2014.
- [18] Tarefder, R.A., White, L., Zaman, M.: Neural Network Model for Asphalt Concrete Permeability, *Journal of Material in Civil Engineering*, 17, pp. 19-27, 2005.
- [19] Semeida, A.M.: Impact of highway geometry and posted speed on operating speed at multilane highways in Egypt, *Journal of Advanced Research*, 4 (2013) 6, pp. 515-523, <http://dx.doi.org10.1016/j.jare.2012.08.014>
- [20] Semeida, A.M.: Application of Artificial Neural Networks for Operating Speed Prediction at Horizontal Curves: a Case Study in Egypt, *Journal of Modern Transportation*, 22 (2014) 1, pp. 20-29, <http://dx.doi.org10.1007/s40534-014-0033-3>